



Revisión sistemática sobre la clasificación de orquídeas mediante redes neuronales convolucionales: arquitecturas viables para Moyobamba

A systematic review of orchid classification using convolutional neural networks: viable architectures for Moyobamba

Karel Stephanie Ramirez Salas ✉

Universidad Católica Sede Sapientiae, Moyobamba, Perú

2022100633@ucss.pe

ORCID: 0009-0003-3270-7457

Yanina Sanchez Calderon

Universidad Católica Sede Sapientiae, Nueva Cajamarca, Perú

yaninasanchezcalderon@gmail.com

ORCID: 0000-0003-2407-9377



<https://doi.org/10.36825/RITI.14.34.004>

Recibido: Mayo 13, 2026

Aceptado: Agosto 22, 2026

Resumen: El presente estudio aborda la limitada identificación de especies de orquídeas en contextos de alta biodiversidad, particularmente en Moyobamba, donde esta situación dificulta su conservación y aprovechamiento en ámbitos turísticos y educativos; por ello, el objetivo es analizar el estado del arte en la clasificación automática de orquídeas mediante redes neuronales convolucionales (CNN). La investigación se desarrolló mediante una revisión sistemática de la literatura basada en la metodología de revisión sistemática de Kitchenham, estructurada en fases de planificación, conducción y reporte, aplicando criterios de inclusión y exclusión a publicaciones entre 2024 y 2026 (con fecha de corte de búsqueda en enero de 2026), lo que permitió seleccionar 22 estudios primarios a partir de 371 registros iniciales. Los resultados evidencian un predominio de arquitecturas como ResNet, DenseNet y MobileNet, así como el uso frecuente de técnicas como *Transfer Learning* y *Data Augmentation*, que mejoran significativamente el rendimiento de los modelos. Se identifican limitaciones relacionadas con la escasez de *datasets* específicos de orquídeas y su implementación en entornos reales. Se concluye que las CNN constituyen una herramienta prometedora para la identificación automática de orquídeas, con potencial aplicación en contextos de biodiversidad tropical como el del Bosque de Protección Alto Mayo.

Palabras clave: *Redes Neuronales Convolucionales, Clasificación de Imágenes, Orquídeas, Revisión Sistemática, Biodiversidad.*

Abstract: This study addresses the limited identification of orchid species in high-biodiversity environments, particularly in Moyobamba, where this issue hinders their conservation and use in tourism and educational contexts; therefore, the objective is to analyze the state of the art in automatic orchid classification using Convolutional Neural Networks (CNNs). The research was conducted through a systematic literature review based on the Kitchenham systematic review methodology, structured into planning, conducting, and reporting phases,

applying inclusion and exclusion criteria to publications from 2024 to 2026 (with a search cut-off date of January 2026), resulting in 22 primary studies out of 371 initial records. The results show a predominance of architectures such as ResNet, DenseNet, and MobileNet, as well as the frequent use of techniques such as Transfer Learning and Data Augmentation, which significantly improve model performance. Limitations related to the scarcity of specific orchid datasets and their implementation in real-world environments were identified. It is concluded that CNNs represent a promising tool for automatic orchid identification, with potential applications in tropical biodiversity contexts such as the Alto Mayo Protected Forest.

Keywords: *Convolutional Neural Networks, Image Classification, Orchids, Systematic Review, Biodiversity.*

1. Introducción

La biodiversidad vegetal constituye uno de los pilares fundamentales para el equilibrio de los ecosistemas y el desarrollo sostenible a nivel mundial [1]. Dentro de esta diversidad, la familia Orchidaceae destaca como uno de los grupos más representativos, con más de 30 000 especies descritas y un número considerable aún por identificar, especialmente en regiones tropicales [2]. Sin embargo, la identificación taxonómica de estas especies requiere conocimientos especializados, lo que limita la generación de información confiable y la participación de la población en procesos de monitoreo y conservación [3].

En América Latina y el Caribe, esta problemática se intensifica debido a la alta concentración de especies en países como Colombia, Ecuador, Brasil y Perú, considerados centros de alta biodiversidad [2]. A pesar del desarrollo de herramientas digitales para la identificación de flora, muchas de estas soluciones no están adaptadas a la diversidad específica de las orquídeas en contextos locales, lo que restringe su aplicabilidad en escenarios reales [4].

En el Perú, se estima la existencia de entre 2 600 y 3 000 especies de orquídeas, distribuidas principalmente en regiones amazónicas como San Martín [5]. En esta región, el Bosque de Protección Alto Mayo representa uno de los principales núcleos de diversidad, concentrando una gran cantidad de géneros y morfoespecies documentadas [6]. No obstante, el acceso a herramientas de identificación continúa siendo limitado para usuarios no especializados, como turistas, estudiantes y comunidades locales [7].

Esta problemática se evidencia en la ciudad de Moyobamba, donde las orquídeas forman parte de la identidad paisajística, cultural y turística. En el Orquidiario Etsa Yumi, el incremento progresivo de visitantes contrasta con una disminución en el acceso a guías especializados y con una brecha entre el número de especies disponibles y aquellas que son efectivamente explicadas durante los recorridos, lo que limita la transferencia de conocimiento [8].

Ante este contexto, la inteligencia artificial ha emergido como una alternativa viable para abordar problemas de clasificación e identificación automática de imágenes. En particular, las redes neuronales convolucionales (CNN) han demostrado un alto rendimiento en tareas de reconocimiento visual y clasificación de especies vegetales [9], [10], [11]. Este enfoque ha mostrado igualmente un alto desempeño en diversas tareas de clasificación de imágenes difundidas en el ámbito iberoamericano, como la comparación de las arquitecturas InceptionV3, VGG16 y ResNet50 [12] o la detección en tiempo real basada en MobileNetV2 [13]. Estas técnicas permiten automatizar el proceso de identificación, reduciendo la dependencia del conocimiento experto y facilitando el acceso a la información.

La revisión sistemática de la literatura (RSL) constituye una metodología fundamental para analizar de manera estructurada el estado del arte en un área específica, permitiendo identificar tendencias, enfoques metodológicos y vacíos de investigación [14]. En este sentido, el objetivo principal de este estudio es realizar una revisión sistemática de la literatura sobre la clasificación de orquídeas mediante redes neuronales convolucionales, con el fin de identificar los principales modelos, técnicas y tendencias actuales, y evaluar su potencial aplicación en contextos de alta biodiversidad como la ciudad de Moyobamba.

Los resultados de esta investigación permiten evidenciar que las arquitecturas basadas en CNN, como ResNet y DenseNet, presentan altos niveles de precisión en la clasificación de especies, y que técnicas como la transferencia de aprendizaje contribuyen significativamente a mejorar su rendimiento. Asimismo, se identifican limitaciones relacionadas con la disponibilidad de datos específicos de orquídeas y su implementación en entornos reales.

El presente artículo se estructura de la siguiente manera: en la sección 2 se describe la metodología empleada para la revisión sistemática; en la sección 3 se presentan los resultados obtenidos; en la sección 4 se discuten los hallazgos; y finalmente, en la sección 5 se exponen las conclusiones del estudio.

2. Metodología

El presente estudio se desarrolló mediante una revisión sistemática de la literatura (RSL), siguiendo las directrices propuestas por Kitchenham [14], las cuales permiten identificar, evaluar y sintetizar de manera rigurosa la evidencia científica disponible en un área específica. El proceso metodológico se estructuró en tres fases principales:

- **Organizar la revisión:** durante la primera fase se definieron las preguntas de investigación, enfocadas en identificar los modelos de redes neuronales convolucionales utilizados en la clasificación de orquídeas, así como las técnicas complementarias, métricas de evaluación y limitaciones en entornos de biodiversidad tropical.
- **Realizar la revisión sistemática:** en la segunda fase se aplicó la cadena de búsqueda en los repositorios científicos seleccionados, junto con los criterios de inclusión y exclusión definidos previamente, con el fin de delimitar el conjunto de estudios relevantes.
- **Reportar los hallazgos:** en la tercera fase se organizó la información recopilada para dar respuesta a las preguntas de investigación planteadas, permitiendo identificar tendencias, enfoques metodológicos y limitaciones en el área de estudio.

2.1. Preguntas de investigación

Las preguntas de investigación fueron formuladas en función del objetivo del estudio, orientadas a analizar el estado del arte en la clasificación de orquídeas mediante redes neuronales convolucionales.

- PI1. ¿Qué modelos de redes neuronales convolucionales se utilizan en la clasificación de orquídeas?
- PI2. ¿Qué técnicas complementarias mejoran el rendimiento de los modelos?
- PI3. ¿Qué métricas se emplean para evaluar el desempeño de los modelos?
- PI4. ¿Qué limitaciones presentan estos enfoques en entornos de biodiversidad tropical?

2.2. Criterios de inclusión y exclusión

Para asegurar que los resultados obtenidos fueran lo más precisos respecto al contexto de investigación, y que los estudios analizados tuvieran la relevancia necesaria para llegar a conclusiones concretas, se definieron criterios de inclusión y exclusión que se aplicaron a los estudios recopilados. Dado que aún no existe un volumen suficiente de estudios centrados exclusivamente en orquídeas, se incluyeron también trabajos sobre clasificación de flores, hojas y plantas en general que emplean CNN, por cuanto sus arquitecturas y técnicas son directamente transferibles al dominio de las orquídeas; esta decisión se retoma como limitación en la discusión. Los criterios de inclusión y exclusión definidos se presentan en la Tabla 1.

Tabla 1. Criterios de inclusión y exclusión.

Identificador	Criterio
CI1	Publicaciones entre 2024 y 2026
CI2	Artículos en inglés o español
CI3	Documentos de acceso abierto (<i>Open Access</i>)
CI4	Uso de redes neuronales convolucionales
CI5	Clasificación de imágenes de plantas u orquídeas
CI6	Estudios con resultados verificables
CE1	Estudios no relacionados con visión por computadora
CE2	Artículos teóricos sin implementación práctica
CE3	Estudios que no utilizan técnicas de <i>Deep Learning</i>

CE4	Artículos duplicados o sin acceso completo
Fuente: Elaboración propia	

2.3. Cadena de búsqueda

La búsqueda de información se realizó en bases de datos científicas reconocidas como IEEE Xplore, Scopus, ScienceDirect, Springer y Wiley Online Library, seleccionadas por su relevancia en el ámbito de la inteligencia artificial y la clasificación de imágenes. La cadena de búsqueda se construyó a partir de los términos clave del objetivo de investigación y sus sinónimos, combinados mediante operadores booleanos (AND, OR). La cadena base fue la siguiente:

(“Convolutional Neural Network” OR “CNN” OR “Deep Learning”) AND (“Orchid” OR “Orchidaceae” OR
 “Flower” OR “Plant”) AND (“Classification” OR “Identification” OR “Recognition”)

Para garantizar la exhaustividad y la reproducibilidad de la revisión, la cadena se adaptó a la sintaxis específica de cada base de datos (campos de título, resumen y palabras clave), restringiendo la búsqueda al periodo 2024-2026. La fecha de corte de la búsqueda se estableció en enero de 2026; en consecuencia, los estudios fechados en 2026 corresponden a publicaciones en acceso anticipado (online first) indexadas antes de dicha fecha. La búsqueda fue ejecutada de forma independiente por las autoras y los desacuerdos se resolvieron por consenso.

2.4. Aplicación de criterios de inclusión y exclusión

Se aplicaron los criterios de inclusión y exclusión de forma estructurada, con el objetivo de obtener estudios relevantes y descartar investigaciones que no se alinearan con el propósito del estudio. Este proceso se llevó a cabo de lo general a lo particular, asegurando la calidad, pertinencia y validez de los trabajos seleccionados. La Tabla 2 resume los criterios aplicados por fase y la Figura 1 presenta el diagrama de flujo PRISMA 2020 [15] del proceso completo de selección. El diagrama PRISMA 2020 se empleó como estándar de reporte para documentar de forma transparente dicho proceso de selección, en complemento de las fases de la metodología de Kitchenham, que constituye el marco que rige la revisión.

Tabla 2. Criterios de inclusión y exclusión por fase.

Fase	Identificador	Criterio
Fase 1	CI1	Documentos publicados entre 2024 y 2026
Fase 1	CI2	Artículos en inglés o español
Fase 1	CI3	Documentos de acceso abierto (<i>Open Access</i>)
Fase 1	CI4	Uso de redes neuronales convolucionales
Fase 1	CI5	Clasificación de imágenes de plantas u orquídeas
Fase 2	CE1	Estudios no relacionados con visión por computadora
Fase 2	CE2	Artículos teóricos sin aplicación práctica
Fase 2	CE3	Estudios que no utilizan <i>Deep Learning</i>
Fase 3	CI6	Resultados experimentales verificables
Fase 3	CE4	Artículos duplicados o sin acceso

Fuente: Elaboración propia.


Durante la primera fase se aplicaron cinco criterios de inclusión (CI1, CI2, CI3, CI4 y CI5). Se filtraron los resultados seleccionando documentos publicados entre los años 2024 y 2026 (CI1), debido a que este rango de tiempo permite obtener una visión actualizada del estado del arte. Asimismo, se consideraron artículos escritos en inglés o español (CI2), disponibles en acceso abierto (CI3), que emplearan redes neuronales convolucionales (CI4) y estuvieran relacionados con la clasificación de imágenes de plantas u orquídeas (CI5). Esta fase permitió reducir el número de estudios de 371 a 28 (Tabla 3).

Tabla 3. Resultados con la cadena de búsqueda.

Fuente	Búsqueda sin filtros	CI 1	CI 2	CI 3	CI 4	CI 5	Total	CE 1	CE 2	CE 3	Total	CI 6	CE 4	Total
IEEE	24	17	17	15	10	7	7	0	0	0	7	7	0	7
Springer	130	63	63	40	12	6	6	0	1	0	5	5	0	5
Wiley	63	23	23	23	4	4	4	1	1	0	2	2	0	2
ScienceDirect	154	99	99	70	20	11	11	1	1	0	9	8	0	8
Total	371	202	202	148	46	28	28	2	3	0	23	22	0	22

Fuente: Elaboración propia

En la segunda fase se aplicaron tres criterios de exclusión (CE1, CE2 y CE3), incorporando filtros de relevancia temática y metodológica. Se eliminaron estudios no relacionados con la clasificación de imágenes o visión por computadora (CE1), trabajos teóricos sin aplicación práctica (CE2) y aquellos que no empleaban técnicas de *Deep Learning* (CE3), lo que permitió asegurar la validez experimental de los resultados. Finalmente, en la tercera fase se aplicaron los criterios CI6 y CE4, orientados a la evaluación específica de los estudios: se seleccionaron investigaciones que presentaran resultados experimentales verificables, eliminando además artículos duplicados o con información incompleta.

**Figura 1.** Diagrama de flujo PRISMA 2020 del proceso de selección de estudios.

2.5. Resultados de criterios aplicados

Como se muestra en la Tabla 3, se presentan los resultados obtenidos tras aplicar los criterios de inclusión y exclusión definidos para esta revisión sistemática. A partir del proceso de búsqueda se identificaron inicialmente 371 estudios, de los cuales 28 fueron considerados relevantes tras la aplicación de los criterios de inclusión. Posteriormente, mediante la aplicación de los criterios de exclusión, el conjunto se redujo a 23 estudios. Finalmente, tras la validación de resultados experimentales y la eliminación de posibles duplicados, se seleccionaron 22 estudios primarios que cumplen con todos los criterios establecidos. A diferencia de otros trabajos, todos los estudios seleccionados presentan implementaciones prácticas basadas en redes neuronales convolucionales y reportan métricas de evaluación, por lo que fueron incluidos en su totalidad en la tabla comparativa principal.

Como resultado del proceso de selección, se obtuvo un conjunto de estudios primarios relevantes para el análisis. En la Tabla 4 se presentan los artículos seleccionados, incluyendo información relevante como el autor, título, fuente, tipo de integración y métricas o resultados, lo cual permite tener una visión general de las características de cada estudio.

Tabla 4. Estudios seleccionados tras la aplicación de criterios.

ID	Autor	Título	Fuente	Tipo de integración	Métricas / Resultados
1	Patel <i>et al.</i> [16]	CNN Flowers Recognition Model	Springer	CNN clásico	85.60% (train), 61.99% (val)
2	Chetia <i>et al.</i> [17]	CNN Plant Leaves Identification	Springer	CNN personalizado	Hasta 99.7% accuracy
3	Juárez-Flores <i>et al.</i> [18]	CNN Flower Classification (VGG, Inception)	Springer	CNN + Transfer Learning	>94% accuracy
4	Peng <i>et al.</i> [19]	Orchid2024 + PEFT	Springer	CNN + Fine-Tuning	Top-1: 86.14%, Top-5: 95.44%
5	Lee <i>et al.</i> [20]	Few-shot Orchid Recognition	Springer	CNN + Few-shot Learning	84.23% - 93.32%
6	Liu <i>et al.</i> [21]	ResNet Spectral Classification	Wiley	CNN + datos espectrales	Alto rendimiento (RMSE bajo)
7	Liu <i>et al.</i> [22]	Multitarget Flower Recognition	Wiley	CNN + Transfer Learning	Alta precisión
8	Hu <i>et al.</i> [23]	OrchidNet	IEEE	CNN + Self-Supervised	Mejora frente a SOTA
9	Chen <i>et al.</i> [24]	Orchid Classification Scheme	IEEE	Deep Learning aplicado	91.4% accuracy
10	Suvarna Vani <i>et al.</i> [25]	Medicinal Flower Detection	IEEE	CNN clásico	94% accuracy
11	Chauhan [26]	EfficientNetB3 Classification	IEEE	CNN moderno (EfficientNet)	98% accuracy
12	Kant <i>et al.</i> [27]	Fine-tuned ResNet Model	IEEE	CNN + Transfer Learning	95% accuracy
13	Bhoomika <i>et al.</i> [28]	EfficientNet Flower Detection	IEEE	CNN + Fine-Tuning	97% accuracy
14	Verma <i>et al.</i> [29]	ResNet Flower Recognition Study	IEEE	CNN clásico	95% accuracy
15	Han <i>et al.</i> [30]	Dendrobium FTIR + CNN	ScienceDirect	CNN + datos espectrales	100% accuracy
16	Xu <i>et al.</i> [31]	Pha-YOLO Detection	ScienceDirect	Deep Learning (detección)	mAP: 98.2%
17	Karimi <i>et al.</i> [32]	Multimodal Flower Classification	ScienceDirect	CNN + multimodal (imagen + texto)	97.17% accuracy
18	Jiang <i>et al.</i> [33]	Chrysanthemum DL Model	ScienceDirect	CNN multistream	95.45% accuracy
19	Li <i>et al.</i> [34]	Gastrodia DL Classification	ScienceDirect	CNN + FTIR	100% accuracy
20	Guo <i>et al.</i> [35]	Lightweight CNN Hybrid Model	ScienceDirect	CNN optimizado	97.42% accuracy
21	Xu <i>et al.</i> [36]	Dendrobium ResNet Authentication	ScienceDirect	CNN + SVM	Hasta 100% accuracy
22	Sangiovanni <i>et al.</i> [37]	OrchID Explainable DL	ScienceDirect	CNN + Explainable AI	F1-score: 0.92

Fuente: Elaboración propia.

Con el fin de facilitar la comprensión de los términos técnicos empleados en el análisis, se estableció un conjunto de abreviaturas relacionadas con los modelos de aprendizaje profundo y las métricas de evaluación. En la Tabla 5 se presentan dichas abreviaturas, las cuales serán utilizadas a lo largo del documento.

Tabla 5. Abreviaturas.

Abreviatura	Término	Abreviatura	Término
CNN	<i>Convolutional Neural Network</i>	DL	<i>Deep Learning</i>
TL	<i>Transfer Learning</i>	DA	<i>Data Augmentation</i>
Acc	<i>Accuracy</i>	Prec	<i>Precision</i>
Rec	<i>Recall</i>	F1	<i>F1-score</i>

Fuente: Elaboración propia.

Asimismo, a partir de la información presentada en la Tabla 4, se analizó la distribución de los 22 estudios primarios según su fuente de indexación, con el fin de caracterizar de manera verificable la procedencia de la evidencia recopilada. Como se aprecia en la Figura 2, la mayor cantidad de estudios provino de ScienceDirect (8) e IEEE Xplore (7), seguidos de Springer (5) y Wiley Online Library (2). Esta distribución refleja la concentración de la producción científica sobre aprendizaje profundo aplicado a la clasificación de plantas en editoriales de alto impacto y evidencia el interés global en la aplicación de estas tecnologías para el análisis de la biodiversidad.




Figura 2. Distribución de los estudios primarios según su fuente de indexación.

2.6. Evaluación de la calidad de los estudios

Con el propósito de reducir el riesgo de sesgo y asegurar el rigor de la evidencia incluida, cada estudio primario fue sometido a una evaluación de calidad basada en una lista de verificación de cinco preguntas (QA1-QA5) adaptada de las directrices de Kitchenham [14]. Cada pregunta se valoró como Sí (1), Parcial (0.5) o No (0), de modo que la puntuación máxima por estudio fue de 5 puntos; únicamente se retuvieron los estudios que alcanzaron una puntuación igual o superior a 3.5, umbral que todos los estudios seleccionados satisficieron. Los criterios de evaluación se presentan en la Tabla 6.

Tabla 6. Criterios de evaluación de la calidad de los estudios.

Identificador	Criterio de calidad
QA1	¿El objetivo del estudio y el problema de clasificación están claramente definidos?
QA2	¿Se describe con detalle la arquitectura CNN y el conjunto de datos utilizado?
QA3	¿Se reportan métricas de evaluación cuantitativas y reproducibles?
QA4	¿Los resultados experimentales son verificables y comparables con otros trabajos?
QA5	¿El estudio discute limitaciones o líneas de aplicación futura?

Fuente: Elaboración propia.

3. Resultados

La presente sección expone los resultados obtenidos a partir de la revisión sistemática de la literatura, considerando los estudios seleccionados que cumplen con los criterios de inclusión y exclusión establecidos. Estos resultados permiten responder a las preguntas de investigación planteadas, centradas en el uso de redes neuronales convolucionales (CNN) para la clasificación automática de plantas y orquídeas.

PI1. ¿Qué modelos de redes neuronales convolucionales se utilizan en la clasificación de orquídeas y qué desempeño alcanzan?

Los estudios analizados evidencian que los modelos basados en redes neuronales convolucionales presentan un alto rendimiento en tareas de clasificación de imágenes de plantas y flores. Diversas arquitecturas como ResNet, EfficientNet y VGG alcanzan niveles de precisión superiores al 90% en múltiples escenarios. Por ejemplo, modelos basados en EfficientNetB3 reportan precisiones de hasta 97% y 98% en la clasificación de flores [26], [28], mientras que arquitecturas como ResNet logran valores cercanos al 95% en diferentes conjuntos de datos [27], [29]. Asimismo, enfoques especializados como OrchidNet demuestran mejoras significativas en la clasificación de orquídeas mediante aprendizaje auto-supervisado [23]. Otros estudios muestran resultados sobresalientes en contextos más complejos, como la identificación de especies medicinales o híbridas, alcanzando precisiones cercanas al 100 % mediante la integración de CNN con datos espectrales [30], [36]. Estos resultados confirman la efectividad de las CNN en la clasificación automática de especies vegetales, incluso en escenarios de alta similitud morfológica.

PI2. ¿Qué técnicas complementarias influyen en el rendimiento de los modelos CNN para la clasificación de especies vegetales?

Se identificaron diversos factores que influyen directamente en el rendimiento de los modelos. En primer lugar, la calidad y el tamaño del *dataset* son determinantes, ya que conjuntos de datos amplios y balanceados permiten mejorar la capacidad de generalización del modelo [23]. Asimismo, el uso de técnicas de preprocesamiento y *Data Augmentation* contribuye a reducir el sobreajuste y mejorar la precisión [18], [24]. Otro factor clave es la arquitectura empleada, donde modelos más profundos y optimizados como EfficientNet y ResNet presentan mejores resultados en comparación con modelos tradicionales [26], [28]. Por otro lado, el uso de *Transfer Learning* permite aprovechar modelos preentrenados, reduciendo el tiempo de entrenamiento y mejorando el desempeño en *datasets* pequeños [25], [27]. Finalmente, la correcta selección de hiperparámetros y optimizadores también influye significativamente en los resultados obtenidos [24].

PI3. ¿Qué métricas y enfoques se utilizan para evaluar y mejorar la clasificación de plantas y orquídeas?

Los estudios revisados evidencian una amplia variedad de técnicas orientadas a mejorar la clasificación, evaluadas principalmente mediante métricas como *accuracy*, precisión, *recall* y *F1-score*. Entre las más utilizadas se encuentra el *Transfer Learning*, aplicado en múltiples investigaciones con modelos como ResNet y EfficientNet [18], [25]. Asimismo, se identifican enfoques más avanzados como el aprendizaje auto-supervisado, implementado en modelos como OrchidNet para reducir la dependencia de datos etiquetados [23]. También destaca el uso de *few-shot learning*, que permite entrenar modelos efectivos con cantidades limitadas de datos, especialmente en el caso de orquídeas [20]. Otros estudios proponen la integración de datos multimodales, combinando información visual y textual para mejorar la precisión del modelo [32]. De igual manera, la fusión de datos espectrales con imágenes ha demostrado ser efectiva en la identificación de especies complejas [21], [30]. Estas estrategias reflejan una tendencia hacia modelos más robustos, eficientes y adaptables a diferentes contextos.

PI4. ¿Qué limitaciones y desafíos presentan los sistemas de clasificación automática en entornos de biodiversidad tropical?

A pesar de los avances, los estudios analizados evidencian diversas limitaciones. Una de las principales es la escasez de *datasets* especializados, especialmente en el caso de orquídeas, lo que dificulta el entrenamiento de modelos robustos [20]. Asimismo, la alta similitud visual entre especies representa un desafío importante para los modelos de clasificación [23], [30]. También se identifica una fuerte dependencia de datos etiquetados, lo cual implica altos costos y necesidad de expertos en el proceso de anotación [20]. Por otro lado, algunos modelos presentan altos costos computacionales, lo que limita su implementación en entornos reales [32]. Finalmente, se

evidencian problemas de generalización, especialmente cuando los modelos son evaluados en condiciones distintas a las de entrenamiento [23].

4. Discusión

A continuación, se discuten los hallazgos más relevantes derivados de los estudios seleccionados, considerando como propósito principal analizar el uso de redes neuronales convolucionales en la clasificación de plantas y orquídeas en contextos reales. En general, las investigaciones revisadas evidencian que los modelos basados en aprendizaje profundo presentan un alto desempeño en tareas de clasificación de imágenes, superando enfoques tradicionales de visión por computadora, especialmente en escenarios con alta variabilidad visual y condiciones no controladas [16], [26], [29].

De manera particular, diversos estudios proponen arquitecturas optimizadas para mejorar la precisión en la identificación de especies. Por ejemplo, Bhoomika *et al.* [28] y Chauhan [26] emplean variantes de EfficientNetB3 ajustadas, logrando mejoras significativas en la clasificación de flores mediante técnicas de *Fine-Tuning*. De forma similar, Kant y Kumar [27] y Verma *et al.* [29] utilizan arquitecturas ResNet, destacando su capacidad para extraer características profundas y mantener estabilidad en conjuntos de datos complejos. Estos enfoques demuestran que la selección y el ajuste de la arquitectura CNN son un factor crítico en el rendimiento del modelo.

Por otro lado, algunos estudios se enfocan en el desarrollo de soluciones específicas para el dominio de las orquídeas. Chen *et al.* [24] proponen un sistema automatizado de clasificación aplicado a líneas de producción, evidenciando la viabilidad industrial de estos modelos. Asimismo, Hu *et al.* [23] presentan OrchidNet, una arquitectura basada en aprendizaje auto-supervisado con fusión multiescala, que logra una mejora en la eficiencia computacional sin sacrificar precisión. En la misma línea, Peng *et al.* [19] introducen un *dataset* especializado, resaltando la importancia de contar con datos de alta calidad para mejorar el desempeño de los modelos.

En cuanto a técnicas avanzadas, Lee *et al.* [20] incorporan mecanismos de atención dual en escenarios de *few-shot learning*, permitiendo la clasificación con pocos ejemplos, lo cual es especialmente útil en contextos de biodiversidad donde los datos son limitados. Asimismo, Karimi *et al.* [32] proponen un enfoque multimodal que combina imágenes y texto, evidenciando mejoras en la robustez del modelo al integrar diferentes fuentes de información. Estas estrategias reflejan una tendencia hacia modelos más complejos y adaptativos.

Adicionalmente, varios estudios exploran la integración de datos espectrales junto con imágenes para mejorar la identificación de especies. Guo *et al.* [35], Xu *et al.* [36] y Li *et al.* [34] combinan espectros FT-NIR o FTIR con redes convolucionales, logrando resultados más precisos en la identificación de especies similares. Sin embargo, estos enfoques requieren equipamiento especializado, lo que limita su aplicabilidad en entornos de campo. En contraste, modelos basados únicamente en imágenes, como los propuestos por Patel *et al.* [16] y Suvana Vani *et al.* [25], ofrecen soluciones más accesibles, aunque con ligeras reducciones en precisión.

Por otra parte, algunos trabajos abordan problemas más específicos como la detección y el conteo de flores. Xu *et al.* [31] proponen Pha-YOLO, un modelo basado en detección multivista que permite identificar y contar flores en condiciones complejas, mientras que Jiang *et al.* [33] emplean fusión de características en diferentes espacios de color para mejorar la clasificación de crisantemos. Estos enfoques amplían el alcance de las CNN más allá de la simple clasificación, incorporando tareas más complejas dentro del análisis visual.

Desde una perspectiva comparativa, los hallazgos permiten distinguir tres grupos de aproximaciones con implicaciones distintas para su transferencia al contexto amazónico. El primero, basado en arquitecturas maduras (ResNet y EfficientNet) con *Transfer Learning*, ofrece el mejor equilibrio entre precisión (95-98%) y facilidad de implementación, por lo que resulta el candidato más viable cuando se dispone de imágenes RGB estándar. El segundo, que integra información espectral (FTIR/FT-NIR), alcanza precisiones cercanas al 100 % pero exige instrumentación de laboratorio, lo que lo hace inviable para el trabajo de campo en un orquidario. El tercero, orientado a la escasez de datos (*few-shot learning* y aprendizaje auto-supervisado, como OrchidNet), es el más pertinente para especies con pocos ejemplares etiquetados, condición habitual en la biodiversidad amazónica. Esta comparación evidencia que la elección de la arquitectura no debe basarse únicamente en la precisión reportada, sino en la disponibilidad de datos y de recursos computacionales del contexto de aplicación.

No obstante, la presente revisión reconoce una limitación de alineación temática: dado que la producción científica centrada exclusivamente en orquídeas es todavía escasa, una parte de los estudios incluidos aborda flores, hojas o plantas en general. Aunque sus arquitecturas y técnicas son transferibles, la generalización directa de sus resultados a las orquídeas debe realizarse con cautela, pues estas presentan una elevada similitud interespecífica y

una gran variabilidad morfológica. Esta constatación revela un vacío de investigación concreto para Moyobamba y la biodiversidad amazónica peruana: la ausencia de *datasets* locales, etiquetados por especialistas, que representen las especies del Bosque de Protección Alto Mayo y del Orquidiario Etsa Yumi. Futuras investigaciones deberían priorizar la construcción de estos conjuntos de datos regionales y la validación de modelos ligeros (*lightweight*) capaces de operar en dispositivos móviles bajo condiciones de campo.

A pesar de los avances, también se identifican limitaciones importantes de carácter general. Varios estudios destacan la dependencia de grandes volúmenes de datos etiquetados, lo que dificulta la generalización de los modelos [18], [21]. Además, la variabilidad en las condiciones de iluminación, fondo y calidad de imagen sigue siendo un desafío significativo en aplicaciones reales. En este sentido, propuestas como OrchID de Sangiovanni *et al.* [37] buscan incorporar explicabilidad en los modelos, permitiendo interpretar las decisiones del sistema y aumentar la confianza en su uso en contextos científicos.

En síntesis, los estudios analizados muestran una clara tendencia hacia el uso de arquitecturas profundas optimizadas, la integración de múltiples fuentes de datos y el desarrollo de soluciones específicas para contextos reales. No obstante, aún existen desafíos relacionados con la disponibilidad de datos, la interpretabilidad de los modelos y su implementación en entornos no controlados. Estos aspectos representan oportunidades clave para futuras investigaciones orientadas a mejorar la aplicabilidad y robustez de los sistemas de clasificación basados en redes neuronales convolucionales en la Amazonía peruana.

5. Conclusiones

La revisión sistemática realizada permitió evidenciar que las redes neuronales convolucionales son altamente efectivas para la clasificación automática de plantas y orquídeas, alcanzando altos niveles de precisión mediante el uso de arquitecturas como ResNet y EfficientNet. Estos modelos han demostrado un desempeño sólido incluso en escenarios con alta similitud entre especies.

Asimismo, se identificó que factores como la calidad del *dataset*, el uso de técnicas de preprocesamiento y la implementación de estrategias como *Transfer Learning* y *few-shot learning* influyen significativamente en el rendimiento de los modelos. Estas técnicas permiten mejorar la capacidad de generalización, especialmente en contextos con datos limitados.

Sin embargo, persisten desafíos como la escasez de *datasets* especializados, la dependencia de datos etiquetados y las dificultades en la aplicación en entornos reales. En este sentido, futuras investigaciones deben orientarse al desarrollo de modelos más eficientes, interpretables y adaptados a contextos de biodiversidad.

En relación con el caso de estudio de Moyobamba, se concluye que las arquitecturas ligeras basadas en *Transfer Learning* (por ejemplo, MobileNet o EfficientNet) y las estrategias de *few-shot learning* constituyen las opciones más viables para una futura implementación en el Orquidiario Etsa Yumi y el Bosque de Protección Alto Mayo, dada la limitada disponibilidad de datos etiquetados de las especies locales. Como recomendación concreta, se propone: (i) construir un *dataset* regional de orquídeas del Alto Mayo, etiquetado con apoyo de especialistas; (ii) desarrollar un prototipo de aplicación móvil de identificación para orientar a turistas y estudiantes durante los recorridos; y (iii) validar los modelos en condiciones reales de campo, contribuyendo así a la conservación y a la puesta en valor turístico y educativo de la biodiversidad amazónica peruana.

6. Agradecimientos

Agradecemos a la Universidad Católica Sede Sapientiae por el apoyo institucional brindado durante el desarrollo de esta investigación, así como a los especialistas del Orquidiario Etsa Yumi de Moyobamba por facilitar el acceso a información sobre la biodiversidad de orquídeas de la región.

7. Referencias

- [1] Akbar, F. A., Sari, C. A. (2025). Orchid species classification using the DenseNet121 deep learning model with a data imbalance handling approach. *Journal of Applied Informatics and Computing*, 9 (6), 3118-3129. <https://doi.org/10.30871/jaic.v9i6.11458>

- [2] Alvian Ideastari, N., Atika Sari, C., Faisal, E., Arifin, Z., Danang Krismawan, A., Muslih, M. (2024). An optimum hyperparameters of ResNet-50 for orchid classification based on convolutional neural network. *Journal of Soft Computing Exploration*, 5 (1), 55-66. <https://doi.org/10.52465/josce.v5i1.297>
- [3] Apriyanti, D. H., Spreeuwens, L. J., Lucas, P. J. F. (2025). Explainable automated wild-orchid identification combining deep neural networks and Bayesian networks. *Engineering Applications of Artificial Intelligence*, 161, 1-17. <https://doi.org/10.1016/j.engappai.2025.111961>
- [4] Bouakkaz, H., Bouakkaz, M., Kerrache, C. A., Dhelim, S. (2025). Enhanced classification of medicinal plants using deep learning and optimized CNN architectures. *Heliyon*, 11 (3), 1-11. <https://doi.org/10.1016/j.heliyon.2025.e42385>
- [5] Shareena, E. M., Chandy, D. A., Shemi, P. M., Poullose, A. (2025). A hybrid deep learning model for aromatic and medicinal plant species classification using a curated leaf image dataset. *AgriEngineering*, 7 (8), 243. <https://doi.org/10.3390/agriengineering7080243>
- [6] Ganesh, C., Harshavardhan, G., Sri Keerthi, N. R., Yabaji, R. V., Rajveer Yabaji, M. S. (2025). Enhancing plant leaf classification with deep learning: Automating feature extraction for accurate species identification. *SCT Proceedings in Interdisciplinary Insights and Innovations*, 3, 1-13. <https://doi.org/10.56294/piii2025513>
- [7] Kutyrev, A., Andriyanov, N. (2024). Apple flower recognition using convolutional neural networks with transfer learning and data augmentation technique. *E3S Web of Conferences*, 493, 1-8. <https://doi.org/10.1051/e3sconf/202449301006>
- [8] Meneses Claudio, B. A. (2024). Development of an image recognition system based on neural networks for the classification of plant species in the Amazon rainforest, Peru, 2024. *LatIA*, 2, 1-13. <https://doi.org/10.62486/latia202415>
- [9] Pathan, A. I., Pandey, S. (2025). Fruit plant recognition and classification from plant leaves using deep learning, CNN models. *International Journal of Recent Technology and Engineering (IJRTE)*, 14 (4), 16-25. <https://doi.org/10.35940/ijrte.D8303.14041125>
- [10] Song, X. (2025). Exploration and research of convolutional neural networks in image recognition. *Applied and Computational Engineering*, 121. <https://doi.org/10.54254/2755-2721/121/2025.19558>
- [11] Suliva, L. B., Bustillo, R. G. (2026). Flora Folium: Plant leaf identification using convolutional neural networks (CNN). *Buana Information Technology and Computer Sciences (BIT and CS)*, 7 (1), 1-8. <https://doi.org/10.36805/cgwb2584>
- [12] Luna Bojórquez, J. L., Ramírez Noriega, A. D., Martínez Ramírez, Y. (2025). Clasificación de imágenes del dataset FBSI por medio de redes neuronales. *Revista de Investigación en Tecnologías de la Información (RITI)*, 13 (32 Especial), 60-73. <https://doi.org/10.36825/RITI.13.32.006>
- [13] Andrade Carrera, H., Sinche Maita, S., Hidalgo Lascano, P. (2021). Modelo para detectar el uso correcto de mascarillas en tiempo real utilizando redes neuronales convolucionales. *Revista de Investigación en Tecnologías de la Información (RITI)*, 9 (17 Especial), 111-120. <https://doi.org/10.36825/RITI.09.17.011>
- [14] Kitchenham, B., Charters, S. (2007). *Guidelines for performing systematic literature reviews in software engineering*. EBSE Technical Report No. EBSE-2007-01. Keele University & Durham University.
- [15] Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., ... Moher, D. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *BMJ*, 372, n71. <https://doi.org/10.1136/bmj.n71>
- [16] Patel, H. N., Modi, N., Bokhani, N. (2024). Efficient Indian flowers recognition model using deep convolutional neural networks. En V. Goar, A. Sharma, J. Shin, M. F. Mridha (Eds.) *Deep Learning and Visual Artificial Intelligence* (pp. 333-341). Springer. https://doi.org/10.1007/978-981-97-4533-3_25
- [17] Chetia, D., Kalita, S. K., Baruah, P. P. P., Dutta, D., Akhter, T. (2025). Identification of traditional medicinal plant leaves using an effective deep learning model and self-curated dataset. En A. Verma, P. Verma, K. K. Pattanaik, R. Buyya, D. Dasgupta (Eds.) *Advanced Network Technologies and Intelligent Computing* (pp. 342-356). https://doi.org/10.1007/978-3-031-83793-7_22
- [18] Juárez-Flores, M., Olguín-Rojas, J. C., Prado-Hernández, J. V., Loaeza-Joachin, J. (2025). Intelligent classification of three floral classes (*Bellis perennis*, *Lavandula angustifolia*, and *Helianthus annuus*)

- utilizing convolutional neural networks. En L. Martínez-Villaseñor, R. A. Vázquez, G. Ochoa-Ruiz (Eds.) *Advances in Soft Computing* (pp. 117-140). https://doi.org/10.1007/978-3-032-08704-1_10
- [19] Peng, Y., Xu, X., Zhang, L., Zhang, J., Wang, Y., Chen, M. (2024). Orchid2024: A cultivar-level dataset and methodology for fine-grained classification of Chinese Cymbidium orchids. *Plant Methods*, 20, 1-15. <https://doi.org/10.1186/s13007-024-01252-w>
- [20] Lee, S. H., Ku, H. C., Zhang, Y. C. (2024). Few-shot learning based on dual-attention mechanism for orchid species recognition. *International Journal of Data Science and Analytics*, 20 (4), 3439-3452. <https://doi.org/10.1007/s41060-024-00671-1>
- [21] Liu, S., Liu, H., Li, J., Wang, Y. (2025). Artificial and algorithmic screening of infrared spectral feature bands of *Gastrodia elata* to achieve rapid identification of its species. *Journal of Chemometrics*, 39 (1). <https://doi.org/10.1002/cem.3641>
- [22] Liu, Q., Hu, Y., Liu, H. (2025). Multitarget recognition of flower images based on lightweight deep neural network and transfer learning. *Advanced Intelligent Systems*, 8 (2), 1-20. <https://doi.org/10.1002/aisy.202500540>
- [23] Hu, W. C., Chen, L. B., Huang, X. R., Huang, G. Z. (2025). OrchidNet: A self-supervised learning-based efficient multiscale feature fusion convolutional neural network with a lightweight architecture for orchid classification. *IEEE Internet of Things Journal*, 12 (5), 5859-5875. <https://doi.org/10.1109/JIOT.2024.3488736>
- [24] Chen, L. B., Huang, X. R., Huang, G. Z., Kuo, S. Y. (2024). An orchid classification scheme using deep learning for automated packaging in production lines. *IEEE Consumer Electronics Magazine*, 14 (1), 65-76. <https://doi.org/10.1109/MCE.2024.3434910>
- [25] Suvarna Vani, K., Kalakota, H. R., Velisala, V., Sree Vijaya Lakshmi, K. (2024). *Medicinal flower detection using CNN algorithm*. 8th International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud). Kirtipur, Nepal.. <https://doi.org/10.1109/I-SMAC61858.2024.10714599>
- [26] Chauhan, S. (2024). *Optimizing flower classification with EfficientNetB3: Insights and results from a high-performance model*. International Conference on Innovation and Novelty in Engineering and Technology (INNOVA). Vijayapura, India. <https://doi.org/10.1109/INNOVA63080.2024.10847051>
- [27] Kant, V., Kumar, K. S. (2025). *Automated flower recognition using fine-tuned ResNet: A solution for efficient botanical classification*. 4th OPJU International Technology Conference (OTCON) on Smart Computing for Innovation and Advancement in Industry 5.0. Raigarh, India. <https://doi.org/10.1109/OTCON65728.2025.11070970>
- [28] Bhoomika, Manchanda, R., Badhani, R., Kharola, A., Singh, R., Gupta, S. (2025). *Deep neural network for flower type detection: A fine-tuned EfficientNetB3 approach*. International Conference on Electrical, Electronics, and Computer Science with Advance Power Technologies - A Future Trends (ICE2CPT). Jamshedpur, India. <https://doi.org/10.1109/ICE2CPT66440.2025.11340009>
- [29] Verma, G., Prasad, C., Mahajan, S. (2024). *Deep convolutional networks for flower species recognition: A ResNet study*. 2nd International Conference on Computational and Characterization Techniques in Engineering and Sciences (IC3TES). Lucknow, India. <https://doi.org/10.1109/IC3TES62412.2024.10877502>
- [30] Han, J., Hu, Q., Wang, Y. (2025). Rapid and accurate identification of *Dendrobium* species using FT-IR, FT-NIR, and data fusion with machine learning. *Industrial Crops and Products*, 234, 1-14. <https://doi.org/10.1016/j.indcrop.2025.121637>
- [31] Xu, D., Huang, X., Zhao, Z., Zhao, Z., Hu, D., Yuan, C. (2026). Pha-YOLO: A multi-view Phalaenopsis flower detection and counting method based on improved YOLO11 with dynamic reference selection and adaptive thresholding. *Computers and Electronics in Agriculture*, 243. <https://doi.org/10.1016/j.compag.2026.111446>
- [32] Karimi, Z., Karamad, M., Rahmany, S. (2025). Enhanced flower image classification: A multimodal approach leveraging Persian texts and deep learning. *Engineering Applications of Artificial Intelligence*, 159. <https://doi.org/10.1016/j.engappai.2025.111642>
- [33] Jiang, J., Yang, X., Yan, H., Liu, J., Chen, Y., Mao, Z., Wang, T. (2026). Chrysanthemum classification method via multi-stream deep color space feature fusion. *Computers and Electronics in Agriculture*, 244. <https://doi.org/10.1016/j.compag.2026.111455>
- [34] Li, G., Li, J., Liu, H., Wang, Y. (2025). Variant identification of *Gastrodia elata* Bl. using deep learning assisted FTIR. *Industrial Crops and Products*, 237, 1-14. <https://doi.org/10.1016/j.indcrop.2025.122313>

- [35]Guo, T., Li, Q., Wang, C., Liu, M., Ge, F., Zhou, X., Zhang, X., Ma, J. (2025). Rapid identification of *Gastrodia elata* Blume hybrids using near-infrared spectroscopy combined with lightweight depthwise separable convolutional neural network. *Microchemical Journal*, 212. <https://doi.org/10.1016/j.microc.2025.113273>
- [36]Xu, Y., Li, L., Wang, Y., Hu, Q. (2025). Novel non-destructive authentication of nine *Dendrobium* species using residual convolutional neural network relying on plant images and FT-NIR spectral information. *Smart Agricultural Technology*, 11, 1-13. <https://doi.org/10.1016/j.atech.2025.101027>
- [37]Sangiovanni, M., Starace, L. L. L., Di Pierro, D., Cozzolino, S., Addonizio, E. (2025). OrchID: Explainable deep learning for *Ophrys* orchid biodiversity monitoring. *Array*, 27, 1-13. <https://doi.org/10.1016/j.array.2025.100480>